

MCMC/EM アルゴリズム/MDL を用いた 床圧力センサからの複数人物位置追跡

佐藤 哲[†]

和田 俊和^{†,††}

加藤 文和^{††}

[†] 株式会社国際電気通信基礎技術研究所

^{††} 国立大学法人和歌山大学

本論文では、圧力の有無を 2 値情報で出力する床圧力センサを用い、床圧力センサ上を歩行する複数の人物を追跡するアルゴリズムを提案する。アルゴリズムは、人物位置の追跡と追跡対象数の推定、及びそれらの対応付けによる統合から成る。まず時系列情報の追跡処理は MCMC (マルコフ連鎖モンテカルロ) 法を採用する。MCMC は適切なモデルを導入することでノイズの混入やセンサ情報の欠落に対しロバストに移動対象の追跡が可能である。ただし MCMC は複数の追跡対象を識別することには適していない。そこで EM (Expectation Maximization) アルゴリズムにより、複数の追跡対象を識別する。さらに EM アルゴリズムの結果に対し MDL (Minimum Description Length) 原理を用いて追跡対象数を推定し、EM アルゴリズムと MDL 原理による推定結果と MCMC による追跡結果を Bhattacharyya 係数によって対応付けを行い、位置追跡を達成する。

Multi-Target Tracking of Human Position using Floor Pressure Sensors based on MCMC/EM Algorithm/MDL

Tetsu Satoh[†]

Toshikazu Wada^{†,††}

Takekazu Kato^{††}

[†]Advanced Telecommunications Research Institute International

^{††}Wakayama University

This paper presents an algorithm for multiple-human tracking using floor pressure sensors which output binary values corresponding to existence of pressure. The algorithm consists of three parts: tracking human positions, estimating the number of tracking targets, and integrating that two kind of information. In this research, the MCMC (Markov Chain Monte Carlo) methods track moving targets robustly in noise and lack of sensor information using a human walking model. However, the MCMC methods are not suitable for distinguishing many tracking targets. Our solution for that problem is using the EM (Expectation and Maximization) algorithm for distinguishing multiple tracking targets, and the MDL (Minimum Description Length) criteria is utilized for estimating the number of tracking targets. The outputs of the MCMC and the EM algorithm are integrated by calculating correspondence with Bhattacharyya coefficient. As a result, human location tracking is achieved.

1 はじめに

人物の位置を計測可能なパッシブ型センサの一つに、床圧力センサがある。本論文では、床圧力センサを用いて複数人物の位置を追跡する手法を述べる。

床圧力センサは空間方向の解像度と、検出できる圧力の強さの解像度により図 1 のような種類に分けられる。このうち、(A) に属するセンサは工場の危険区域進入検知や自動ドアの開閉に使われており、スイッチとして用いられている。(B) に属するセンサは本研究で使用するもので、ヴェイストン株式会社[†] のセンサフロアシステムのような製品がある。(C) に属するセンサは、Georgia Tech Aware Home の Smart Floor[1] や Olivetti and Oracle Research (ORL, 当時) の Active Floor[2] で用いられている。(D) に属するセンサは、Tekscan 社^{††} の MatScan システムや XSENSOR Technology 社^{†††} の XSENSOR pressure mapping システムなど、多くの製品がある。こ

れらの中で、人物追跡に適すると考えられるのは、(B) 及び (C) である。その理由は、まず (A) は小型のものを大量に使用すれば (B) と同様になるが、通常 (A) のセンサは複数のセンサと協調するようには設計されていないことが多いために、大量のセンサ情報を統合するコントローラが必要となる。(D) のセンサは耐久性が問題となり、またセンサの価格が非常に高価である。さらに本研究に対しては、(B) は次のような問題がある。(B) は空間的な精度が低い代わりに測定値の精度が高いので、複数の測定値を補間することで空間的な精度を高めることが多い。しかし、複数の人物が空間精度以下の領域にいる場合、その手法は使用不可能である。従って複数の人物が存在する場合の人物追跡には (C) のセンサが使用できる可能性があるため、本研究では以下のようなスペックの (C) に分類されるセンサを用いる。このセンサは、ヴェイストン社のセンサフロアシステム VS-SS-SF55 である (図 2)。

- 空間精度は 18cm×18cm
- 圧力検知精度は、約 200g/cm² 以上の圧力で

[†]<http://www.vstone.co.jp/>

^{††}<http://www.tekscan.com/>

^{†††}<http://www.xsensor.com/>

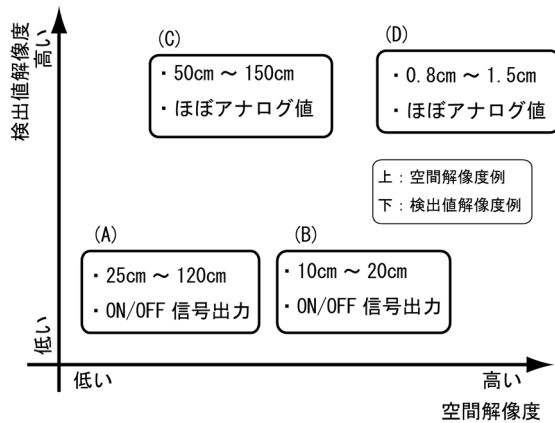


図 1: 圧力センサの分類




図 2: 床圧力センサ

ON を出力

圧力センサによる人物位置推定は、画像や音声など 2 次的な信号を元に人物位置を推定する手法と比べ直接的に人物と接触するため、高速で確実な位置取得が可能なが期待される。しかし実際には以下のような問題があり、確実な位置取得は難しい。

- 誤検出問題
人物以外の家具や生活用品に対しても圧力センサは反応し、しばしば人物と区別がつかないセンサ情報を出力する。また重い家具などによりセンサが劣化し、物体が上に存在しないにも関わらず圧力反応を出力する場合がある。
- 未検出問題
美観の問題と圧力センサ保護の観点より、圧力センサの上にカーペットなどを被せる場合が多い。その場合、圧力の吸収が発生して圧力反応の未検出が発生する。

さらに、本研究で使用する圧力センサは 2 値型であるために複数の人物を認識することや人物の移動を追跡することは難しい。

以上のように、床圧力センサは、出力信号が不安定であり、得られる情報量は少なく信頼度も低い。このような問題に対しては、ある程度の変動や誤差を許容するような統計確率的なアルゴリズムが有効である。本研究では、マルコフ連鎖モンテカルロ法

(MCMC) によるノイズや信号の欠損に対しロバストな位置追跡法を採用する。しかし MCMC には、複数の追跡対象毎に別々の MCMC を適用した場合に MCMC 同士の協調動作が難しい、追跡対象の数の変動に対応することが難しいなどの問題がある。そこで EM アルゴリズムを用いて MCMC の追跡対象数を推定する。追跡する人物の数の変動を判断する規準には、MDL 原理を用いる。

2 MCMC による時系列信号追跡

2.1 MCMC による状態推定

信号にノイズや欠損が多い場合に有効なアプローチとして、マルコフ連鎖モンテカルロ法 (MCMC) がある。MCMC と呼ばれるクラスに分類される手法には膨大な研究があるが [3]、本研究で用いる手法は時系列の信号入力に対しデータの再サンプリングを繰り返しながら逐次的に保持データを更新していく逐次的モンテカルロ法と呼ばれる手法である。逐次的モンテカルロ法は様々なモデルに対し適用されており、ブートストラップ・フィルタ [4]、モンテカルロ・フィルタ [5]、CONDENSATION アルゴリズム [6] などとも呼ばれている。以下では逐次的モンテカルロ法を MCMC と呼ぶ。

MCMC は、次のような時系列状態空間モデルを用いる：

$$\mathbf{x}_{n+1} = F(\mathbf{x}_n, \boldsymbol{\omega}_n) \quad (1)$$

$$\mathbf{y}_n = H(\mathbf{x}_n, \boldsymbol{\omega}'_n) \quad (2)$$

ここで、 \mathbf{x} は状態ベクトル、 \mathbf{y} は観測値である。 $\boldsymbol{\omega}$ 及び $\boldsymbol{\omega}'$ は白色雑音で、それぞれシステムノイズ、観測ノイズと呼ばれる。関数 F 及び H は任意の関数で、関数を固定した時、式 (1) をシステムモデル、式 (2) を観測モデルと呼ぶ。この時系列状態空間モデルを用いて、観測値 \mathbf{y} から状態 \mathbf{x} を推定することが目的である。

推定する状態 \mathbf{x} は、確定値ではなく確率分布によって表される。一般にはその確率分布が初等的な関数で表されるとは限らないため、確率分布 p は N_p 個の粒子 f によって近似される。これを次のように表す：

$$\{f_n^{(1)}, f_n^{(2)}, \dots, f_n^{(N_p)}\} \sim p(\mathbf{x}_n | \mathbf{y}_n) \quad (3)$$

式 (3) は、時刻 t_n での観測値 \mathbf{y}_n から MCMC が推定した状態 \mathbf{x}_n の確率分布が、粒子によって $\{f_n^{(1)}, f_n^{(2)}, \dots, f_n^{(N_p)}\}$ という形で保持されることを表す。以下、 $f_n^{(i)}$ を求める手法を述べる。

2.2 予測と再サンプリング

時刻 t_{n-1} の状態 \mathbf{x}_{n-1} を表す粒子分布 $f_{n-1}^{(i)}$ が与えられているとする。また、あらかじめシステムノイズを表す確率分布 $\boldsymbol{\omega}_n$ を近似する粒子 $\boldsymbol{\omega}_n^{(i)}$ が生成されているとする。すると、時刻 t_{n-1} の観測値 \mathbf{y}_{n-1} から現在の状態を推定する分布 $p(\mathbf{x}_n | \mathbf{y}_{n-1})$ を近似するための粒子が、次のように計算できる：

$$p_n^{(i)} = F(f_{n-1}^{(i)}, \boldsymbol{\omega}_n^{(i)}) \quad (4)$$

式 (4) は、システムモデルが与えられていればモデルに基づいた推定ができることを表しており、 $p_n^{(i)}$ を予測分布と呼ぶ。

次に、予測分布に対し現在の観測値を考慮して修正を加えることを考える。そのためにまず、実際の観測値 \mathbf{y}_n とシステムモデルからの予測である粒子 $p_n^{(i)}$ の間の違いを尤度 $\alpha_n^{(i)}$ として次のように計算する：

$$\alpha_n^{(i)} = r(G(p_n^{(i)}, \mathbf{y}_n)) \left| \frac{\partial G}{\partial \mathbf{y}_n} \right| \quad (5)$$

ここで、 r は観測ノイズ ω'_n の密度関数、 G は観測モデルを表す関数 H の逆関数で $\omega'_n = G(\mathbf{x}_n, \mathbf{y}_n)$ で定義される。ただしここでは \mathbf{x}_n は粒子で近似されているので、 $\omega'_n = G(\mathbf{x}_n, \mathbf{y}_n) \sim G(p_n^{(i)}, \mathbf{y}_n)$ となる。そして粒子の集合 $\{p_n^{(1)}, p_n^{(2)}, \dots, p_n^{(N_p)}\}$ から、 $\alpha_n^{(i)}$ に比例した確率で粒子を再サンプリングして $f_n^{(i)}$ とする。再サンプリングは多くの手法が提案されているが、本研究ではまず次の式を満たすような j を探索し、

$$\frac{\sum_{k=1}^{j-1} \alpha_n^{(k)}}{N_p} < \frac{j-1/2}{N_p} \leq \frac{\sum_{k=1}^j \alpha_n^{(k)}}{N_p} \quad (6)$$

その j に対応する粒子 $p_n^{(j)}$ により状態 \mathbf{x}_n を近似する粒子を割り当て直す：

$$f_n^{(i)} = p_n^{(j)} \quad (7)$$

このように計算された $f_n^{(i)}$ は、 $p(\mathbf{x}_n | \mathbf{y}_n)$ すなわち観測値 \mathbf{y}_n が得られた時に推定される状態 \mathbf{x}_n の確率分布を近似している。位置追跡の場合は、例えば $\{f_n^{(1)}, f_n^{(2)}, \dots, f_n^{(N_p)}\}$ の平均値や密度が最も高い点の値を計算することで、推定位置とすることができる。

2.3 MCMC による複数対象追跡

MCMC のような確率的なアルゴリズムを用いて複数の時系列信号を追跡する場合、大きく二通りの手法が考えられる [7]。一方は一つの MCMC が十分な数の粒子を用いて全ての対象の位置を表し同時に複数の対象を追跡する方法 [8][9] で、他方は対象毎に別々の MCMC が追跡し、複数の MCMC アルゴリズムを実行することで複数の対象を追跡する方法 [10][11] である。前者の場合は、式 (3) のように追跡対象の位置を表現した場合、一つの追跡対象に対し約 N_p 個の粒子を用いるとすると、追跡対象数が m 個の場合は粒子数は $N_p \times m$ となり、計算量・記憶量が大きくなるのが問題となる。例えば追跡対象に重なりが生じない場合、複数の MCMC アルゴリズムを実行する方が大幅に粒子数が少なく済むことが報告されている [12]。そのため、本研究では後者のアプローチを採用する。このアプローチにより複数の MCMC アルゴリズムを独立に実行する場合、追跡対象の存在領域を限定す

るなどにより粒子数を減らすことが可能である。我々のアプローチに対する関連研究としては、有限集合統計 (Finite Set Statistics:FISST) を用いた確率仮説濃度 (Probability Hypothesis Density:PHD) フィルタを用いた複数対象追跡 [13] があげられる。PHD フィルタを用いた手法は、十分な数の粒子を用いて全ての追跡対象を表す点は前者と同様だが、 $N_p \times m$ 次元空間で確率分布を評価する代わりに、確率分布を積率 (モーメント) 展開した時の 1 次の項だけを計算し確率分布の近似とみなすことで計算量を減らす手法である。

複数対象を追跡する場合のもう一つの問題は、対象の数を推定することである。対象数の推定方法には、追跡対象の位置とは別に推定する手法 [10][9][11]、追跡対象数を MCMC の状態空間の中で位置と同時に推定する手法 [8] がある。本研究の目的は実時間の複数対象追跡なので、計算量が少ない前者のアプローチを採用する。PHD フィルタを用いた手法では、PHD に総和が分布数を表す特性があるために PHD の評価から自然に追跡対象を推定可能である。しかし計算量の面では、PHD フィルタを用いるよりも次節にて述べる EM アルゴリズムを用いて複数の MCMC アルゴリズムを制御する方が有利であると考えられる。

3 EM アルゴリズムによるクラス分類

3.1 EM アルゴリズム

EM アルゴリズム [14] は、直接観測することができない隠れ変数を導入した統計モデルに対し、モデルパラメータの最尤推定値を数値的に求めるアルゴリズムである。パラメータ推定は、与えられた初期値から反復計算により確率分布の尤度の局所的最大値を与えるパラメータとして計算される。この時、反復過程で尤度の単調増加性 [14] のために安定に解が求まる、分布が混合正規分布の場合に特に簡潔な形で定式化されるので高速である、などの特徴がある。センサ情報からの物体追跡問題に対しては実時間性が求められるため、計算コストの低さは重要な要素である。

EM アルゴリズムは一般に次のように定式化される。まず、 \mathbf{y} を観測値、 \mathbf{x} を隠れ変数とする。そしてアルゴリズムの目的を、観測値 \mathbf{y} が与えられた時に \mathbf{x} を含む完全データ (\mathbf{x}, \mathbf{y}) に対する確率モデル $p(\mathbf{x}, \mathbf{y}; \theta)$ の対数尤度 $\log p(\mathbf{x}, \mathbf{y}; \theta)$ を最大にするパラメータ θ を求めることとする。そのアルゴリズムは、次のように表される：

E(Expectation) ステップ

対数尤度の条件付期待値を計算する：

$$Q(\theta | \theta^{(t)}) = \sum p(\mathbf{x} | \mathbf{y}; \theta^{(t)}) \log p(\mathbf{x}, \mathbf{y}; \theta) \quad (8)$$

ここで総和は全ての \mathbf{x}, \mathbf{y} について和を取ることを表す。また、 $p(\mathbf{x} | \mathbf{y}; \theta^{(t)})$ は次のように計算

することができる：

$$p(x|y; \theta^{(t)}) = \frac{p(x, y | \theta^{(t)})}{\sum p(x, y | \theta^{(t)})} \quad (9)$$

ここで総和は全ての y について和を取ることを表す。

M(Maximization) ステップ

$Q(\theta|\theta^{(t)})$ の最大値を与える θ を $\theta^{(t+1)}$ とする。

3.2 混合正規分布に対する EM アルゴリズム

確率モデルとして、次のような混合正規分布を考える：

$$p(y; \theta) = \sum_{i=1}^m \xi_i p_i(y; \theta_i) \quad (10)$$

ここで、

$$p_i(y; \theta_i) = \frac{1}{(2\pi)^{d/2} \sqrt{|\Sigma_i|}} \exp\left(-\frac{(y - \mu_i)^T \Sigma_i (y - \mu_i)}{2}\right),$$

$$\sum_{i=1}^m \xi_i = 1,$$

各 μ_i は分布の平均、各 Σ_i は分布の分散共分散行列、 d は y の次元、 m は正規分布の数である。 θ は分布のパラメータである μ_i や Σ_i を示す。そして N 個の観測値 y_i に対し、 y_i が m 個の正規分布のうちどの正規分布から生成されたかは観測ができないため、 y_i を生成した分布を示す指標 J_i を隠れ変数とする。この場合、EM アルゴリズムにより推定するパラメータは重み ξ_i 、分散共分散行列 Σ_i 、平均 μ_i である。また、対数尤度は次のようになる：

$$Q(\theta|\theta^{(t)}) = \sum_{i=1}^m \sum_{j=1}^N p(J_i|y_j; \theta_i^{(t)}) \log \xi_i p_i(y_j; \theta_i) \quad (11)$$

ただし

$$p(J_i|y_j; \theta_i^{(t)}) = \frac{\xi_{J_i} p_{J_i}(y_j; \theta_{J_i}^{(t)})}{\sum_{k=1}^m \xi_k p_k(y_j; \theta_k^{(t)})} \quad (12)$$

このモデルに対しては、対数尤度を最大にするパラメータは、パラメータによる微分値をゼロとおいた極値を求める方程式を解くことで得られる。まず、 $Q(\theta|\theta^{(t)}) + \lambda(\sum_{i=1}^m \xi_i - 1)$ を λ 及び ξ_i で微分した式をゼロとおき、 ξ について解くことで次式が得られる：

$$\xi_j^{(t+1)} = \frac{1}{m} \sum_{i=1}^m p(J_j|y_i; \theta_j^{(t)}) \quad (13)$$

また、 $Q(\theta|\theta^{(t)})$ を μ_i 及び Σ_i で微分した式をゼロとおき、 μ_i や Σ_i について解くことにより、次のよう

な式が得られる。

$$\mu_j^{(t+1)} = \frac{1}{m \xi_j^{(t+1)}} \sum_{i=1}^m p(J_j|y_i; \theta_j^{(t)}) y_i \quad (14)$$

$$\Sigma_j^{(t+1)} = \frac{1}{m \xi_j^{(t+1)}} \times \sum_{i=1}^m p(J_j|y_i; \theta_j^{(t)}) (y_i - \mu_j^{(t+1)})(y_i - \mu_j^{(t+1)})^T \quad (15)$$

そして t についてのループを式 (11) の値が十分収束するまで繰り返すことで、パラメータが推定される。

4 MDL によるモデル選択

4.1 MDL 原理

MDL 原理 [15] は情報論的な符号化手法の一つで、情報源モデルを符号化した時の符号語長とそのモデルを用いて符号化したデータの符号語長の和が最小になるものを選択する。符号語長は、以下のように計算する。

まず、 N 個の観測データから、情報源モデルのパラメータを EM アルゴリズムなどの最尤推定を用いて推定する。推定されたパラメータを $\hat{\theta}$ 、パラメータ数を N_θ とすると、情報源モデルの最適符号化の符号長 $L(\hat{\theta})$ は次のように表される：

$$L(\hat{\theta}) = \frac{N_\theta}{2} \log_2 N \quad (16)$$

また、情報源モデルの確率密度関数を $p(y; \hat{\theta})$ とすると、観測データを符号化した場合の符号長 $L(y; \hat{\theta})$ は次のようになる：

$$L(y; \hat{\theta}) = - \sum_{i=1}^N \log_2 p(y_i; \hat{\theta}) \quad (17)$$

従って、MDL 原理では次の量を最小にするモデルを選択する：

$$L = L(\hat{\theta}) + L(y; \hat{\theta}) \quad (18)$$

$$= \frac{N_\theta}{2} \log_2 N - \sum_{i=1}^N \log_2 p(y_i; \hat{\theta}) \quad (19)$$

4.2 混合正規分布に対する MDL 原理

式 (10) で表される混合正規分布を考える。まず情報源の符号化を考えると、 d 次元の観測データ N 個より推定されるパラメータは、 m 個の正規分布の d 次元平均が m 個、分散共分散行列の成分が $m \times (d + (d^2 - d)/2)$ 個、各正規分布の重みが m 個で、合計で

$$m(d + d + (d^2 - d)/2 + 1) = m(d + 1)(d + 2)/2 \quad (20)$$

の数だけある。従って情報源の符号長は

$$L(\hat{\theta}) = \frac{m(d + 1)(d + 2)}{4} \log_2 N_\theta \quad (21)$$

となる。ただし、 $\log_2 N_{\theta} d = \log_2 N_{\theta} + \log_2 d$ であり、モデル選択を行う場合はデータの次元 d は固定するのが普通なので、 $\log_2 N_{\theta} d$ の代わりに $\log_2 N_{\theta}$ としても符号長の比較には影響を与えない。よって本研究では $\log_2 N_{\theta}$ を採用する。次に観測データの符号長を考えると、式 (10) と式 (17) より

$$L(y; \hat{\theta}) = - \sum_{j=1}^N \log_2 \sum_{i=1}^m \xi_i p_i(y_j; \hat{\theta}_i) \quad (22)$$

となる。従って混合正規分布に対する符号長は次のようになる。

$$\begin{aligned} L &= L(\hat{\theta}) + L(y; \hat{\theta}) \\ &= \frac{m(d+1)(d+2)}{4} \log_2 N_{\theta} - \sum_{j=1}^N \log_2 \sum_{i=1}^m \xi_i p_i(y_j; \hat{\theta}_i) \end{aligned} \quad (23)$$

5 MCMC/EM アルゴリズム/MDL による複数人物追跡

5.1 人物位置追跡モデル

本研究では、人物の移動モデルは単純なガウシアンモデルを用いる。本研究で使用した圧力センサと同等の床圧力センサから人物移動を追跡する手法として人物の二足歩行を考慮したモデルが提案されているが [16]、現実生活空間の中に圧力センサを敷設した場合、理想的に両足の反応が得られることは有り得ないと考えられることから、ガウシアンモデルが妥当であると言える。まず、式 (1) で表される MCMC のシステムモデルは、次のように過去の移動経路の推移に従う可能性が高く、かつ正規分布に従う乱数パラメータを要素とするモデルを採用する：

$$x_{n+1} = F(x_n, \omega_n) = x_n + v_n \Delta t + \omega_n \quad (24)$$

ここで、 x_n は n ステップ目の追跡対象物体の位置、 v_n は過去の位置から推定した速度、 Δt は時間係数、 ω_n は正規分布 $N(0, \sigma^2)$ に従う白色雑音である。次に、式 (2) で表される観測モデルは、次式を用いた：

$$y_n = H(x_n, \omega'_n) = x_n + \omega'_n \quad (25)$$

ここで、 y_n は観測結果として得られる追跡対象物体の位置、 ω'_n は ω_n と同様の白色雑音である。

5.2 人物数推定モデル

本研究では、圧力センサ情報に対し式 (10) で表される混合正規分布モデルを当てはめることで人物数を推定する。また、圧力センサ情報は平面上の位置を出力するので次元 $d = 2$ とする。ただし本研究で用いるような圧力センサは、反応数が少なく EM アルゴリズムを用いて混合正規分布モデルのパラメータを推定することが困難である。例えばセンサより得られたサンプル点の数が 1 点あるいは 2 点の場合、

パラメータを推定すると分散共分散行列の成分の値がゼロに近くなり、正規分布の計算が破綻するようなことが発生する。そこで本研究では、式 (7) により MCMC が発生した粒子群に対し EM アルゴリズムを適用する。ただし全ての粒子を用いると複数人物の識別が困難になるので、粒子の尤度を考慮して計算する。この方法により、安定して EM アルゴリズムが動作する。複数の MCMC が人物一人を追跡してしまつた場合に、EM アルゴリズムが粒子群をまとめる働きをするので改めて人物一名と認識できる、などの利点が生まれる。人物数の推定方法を以下に述べる。

まず、 $t = t_{n-1}$ の時点の人物数を M とし、EM アルゴリズムを用いて混合正規分布のパラメータ $\hat{\theta}_M$ を推定する。続いて人物数を $M-1$ 、 $M+1$ と仮定した場合のパラメータ $\hat{\theta}_{M-1}$ 、 $\hat{\theta}_{M+1}$ を推定する。そして式 (23) を用いて、各推定パラメータに対する符号長 $L(\hat{\theta}_M)$ 、 $L(\hat{\theta}_{M-1})$ 、 $L(\hat{\theta}_{M+1})$ を計算し、符号長が最小になる人物数を $t = t_n$ での人物の数と推定する。従って本研究では、追跡対象数が同時に 2 以上変化する場合は想定外とする。

5.3 MCMC-EM アルゴリズム対応付けと消滅テーブル生成

前節で示した方法で人物数の推定が可能だが、時系列的な対応は考慮されない。本節では MCMC の位置推定結果と EM アルゴリズムの位置推定結果を対応付けることで時間的・空間的な追跡を達成する方法を述べる。

本研究では、MCMC が粒子によって近似している確率分布と EM アルゴリズムがパラメータを推定した確率分布の間で、以下のように定義される Bhattacharyya 係数 [17] を計算することで類似性を判定し、対応付けを計算する。

$$\rho_{jk} = \sum_{i=1}^{N_p^{(j)}} \sqrt{p_M^{(j)}(x_i^{(j)}) p_E^{(k)}(x_i^{(j)})}.$$

ここで、 $N_p^{(j)}$ は j 番目の MCMC の粒子数で、 p_M は粒子より推定した確率密度関数の正規化されたヒストグラム値、 p_E は EM アルゴリズムにより推定されたパラメータを持つ、混合正規分布の中の k 番目の正規分布の正規化されたヒストグラム値である。 p_M は追跡を実行している MCMC の個数 N_{mcmc} だけ種類があり、 p_E は MDL 原理により判断した EM アルゴリズムの正規分布の個数 N_{em} だけ種類がある。従って対応付けは、 ρ_{jk} を成分とする $N_{mcmc} \times N_{em}$ の行列から値の大きい成分を探索することになる。 N_{mcmc} と N_{em} は等しいとは限らないので、対応が付かなかつた場合の処理が必要になる。

本研究では、 $N_{mcmc} \geq N_{em}$ を仮定する。この仮定は、前節で述べたように MCMC の尤度が大きい粒子に対して EM アルゴリズムを適用しているため、一つの MCMC 粒子群に対して EM アルゴリズムが

複数の正規分布と判定することは稀であるために妥当だと言える。従って対応が付かない場合はMCMCが追跡対象としていた対象が消滅した場合と考えることができる。ただし本研究で用いる床圧力センサに対しては、追跡対象が観測領域外に移動して実際に追跡対象からはずれる場合の他に、センサの未検出によって対象の消滅とみなされる可能性がある。そのため対応が付かなかったMCMCの推定位置を、そのMCMCを示すID情報とともにテーブルに保存し、そのテーブルを消滅テーブルと呼ぶ。消滅テーブルは、新たなセンサ反応が得られた場合に、実際に人物数が増加したのか追跡失敗が回復したのかという判定に使用される。この消滅テーブルは、データ対応付け変数 [11][18] の概念と同様のものである。

5.4 複数人物追跡処理

前節までに述べた手法を用い、以下の1~4の処理を繰り返すことで複数人物を追跡する。

1. MCMCによる人物位置追跡

まず、 $t = t_n$ の時点の圧力センサ情報を取得する。圧力センサ情報は、 Q 個の (x, y) 座標で得られるとする。そして $t = t_{n-1}$ の時点で実行されていたMCMCに対し、距離を計算することで圧力センサによる位置情報とMCMCとの対応を計算する。 $t = t_{n-1}$ の時点で実行されていたMCMCの個数を M_{n-1} 個とする。

- $Q \geq M$ の場合、圧力センサ座標を元に $(Q-M)$ 個のMCMCに対し追跡処理を開始させ、MCMCの個数を Q 個とする。消滅テーブルに近い座標があればIDを取り出してMCMCに割り当て、消滅テーブルからは削除する。消滅テーブルに対応する座標がなければ新規にIDを割り当てる。そして Q 個の圧力センサ情報を元にMCMCを実行し、 $t = t_n$ での人物位置を推定する。
- $Q < M$ の場合、圧力センサ座標と対応の付かなかった $(M-Q)$ 個のMCMCに対し、 $t = t_{n-1}$ でのMCMCの推定座標を $t = t_n$ での推定座標とする。対応がついた Q 個のMCMCについては、 Q 個の圧力センサ情報を元にMCMCを実行し、 $t = t_n$ での人物位置を推定する。

2. EMアルゴリズムによる人物数候補推定

MCMCが発生した粒子に対し、正規分布の個数を $M_{n-1} - 1$, M_{n-1} , $M_{n-1} + 1$ と変化させてEMアルゴリズムを実行し、パラメータ $\hat{\theta}_{M_{n-1}-1}$, $\hat{\theta}_{M_{n-1}}$, $\hat{\theta}_{M_{n-1}+1}$ を推定する。

3. MDL原理による人物数推定

記述長が最小になる $\hat{\theta}_x$ を採用し、その時の $x \in \{M_{n-1} - 1, M_{n-1}, M_{n-1} + 1\}$ を人物数 M_n とする。

4. Bhattacharyya 係数による対応付け

M_{n-1} 個のMCMCの分布と M_n 個のEMアルゴリズムの推定した正規分布の全ての組み合わせに対しBhattacharyya係数を計算し、係数が大きくなるもの同士を対応付け、MCMCの持つIDを対応するEMアルゴリズムの分布に割り当てる。対応が付かなかった場合、追跡対象の人物が減少したと判断してそのMCMCの座標を消滅テーブルに入れ、結果として追跡処理を行うMCMCの個数を M_n 個とする。

6 複数人物追跡実験

本節では、提案手法を用いた実験結果を述べる。実験は、部屋の中に敷設されている床圧力センサからの情報を約200ミリ秒ごとにサンプリングし2次元座標のリストを生成し、そのリストに対し提案手法を適用することで行った。ただし圧力センサ以外の問題を除外して検討するため、人物の移動中に圧力センサ情報を取得して保存し、保存データをファイルから読み込み提案手法を適用した。部屋の大きさは約5.7メートル×8.5メートルである。以下、5.4節で述べた1~4の一連の処理を実行することを1ステップと呼ぶ。システムはCPUがIntel Pentium 4(3.06GHz)のFreeBSDマシン上にgcc 3.4.2を用いて実装され、以下に述べるパラメータでの1ステップの実行時間は約10ミリ秒である。

実験に用いたモデルパラメータは次の通りである。まず、式(24)で表されるシステムモデルの速度推定は2ステップ前の推定位置座標からの座標成分の差を用いた。そして $\Delta t = 0.5$ とした。式(24)及び式(25)の白色雑音は、メルセンヌ・ツイスター法 [19] で生成した一様乱数に対しBox-Müller変換を適用し作成した。システムモデルに対する分散は0.5、観測モデルに対しても0.5を用いた。MCMCの粒子数は一つの追跡対象に対し200個で、最大追跡対象数を20としたので合計では2000個の粒子を使っている。EMアルゴリズムは、各粒子が保持している尤度(5)を利用し、一つの対象の追跡に使われている粒子の尤度の最大値を求め、最大値の0.85倍以上の大きさの尤度を持つ粒子に対し適用した。

図3は、100ステップ追跡した2名の人物の歩行軌跡を表す。ただし真の位置を測定する機材を保有していなかったため、図3は圧力センサデータより人間が人物位置を判断した結果から作成した。実線で表される歩行軌跡を持つ人物をID=1、点線で表される歩行軌跡を持つ人物をID=2とする。時系列的には、始めにID=1の人物が部屋の左端付近におり、その後部屋の右端からID=2の人物が進入してくる。2名の人物は家具等を避けながら接近するが、気まぐれな方向への移動も含まれる。そして実験の終了間際にはID=1の人物がイスに座ることで観測対象から除かれ、ID=2の人物だけが残る。




図 3: 正解とする軌跡

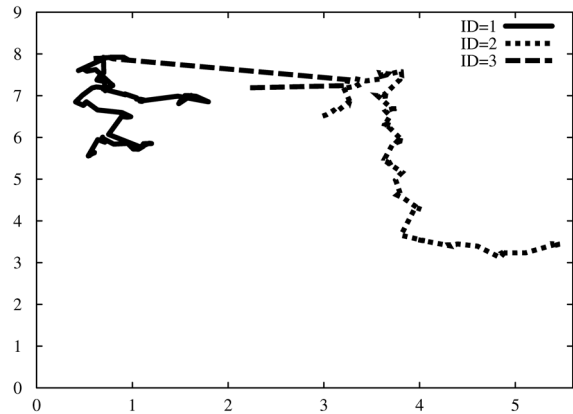


図 4: MCMC が推定した歩行軌跡

図 4 は、圧力センサデータより MCMC が人物位置を推定した結果を表している。図 3 と比較すると良好に追跡されていることが分かるが、ノイズの影響により ID=3 という存在しない人物の追跡が発生している。図 5 は、MCMC の粒子を利用して EM アルゴリズムが推定した人物位置を表している。ID=3 の人物は発生していないが、ID=1 及び 2 の 2 名が近付いた場合に MCMC と比べ位置推定精度が低くなっていることが分かる。ただし本研究では、圧力センサ情報の信頼性は高くないので、推定精度の低さが蓄積しなければ問題ないと考えられる。図 4～図 5 の縦軸及び横軸の単位はメートルである。




図 5: EM アルゴリズムが推定した歩行軌跡

図 6 は、実験中に圧力を検知したセンサの数と、EM アルゴリズムと MDL 原理を用いて推定した人物数を縦軸に表す。横軸はステップ数である。図の最下部に水平方向の矢印とともに記述されている数字が、真の人物数である。EM アルゴリズムの特性により、実験後半の人物同士が近付いている場合に推定の失敗が増えていることが分かる。しかし推定の失敗は局所的で、追跡の継続に影響は与えていない。それを示すために、図 7 に EM アルゴリズムが推定した ID 別の x 座標を時系列で示す。途中で未検出期間が存在するにも関わらず、 x 座標が小さく部屋の左側に位置する追跡対象が ID=1、右側に位置する追跡対象が ID=2 と、追跡開始から終了まで正しく認識されていることが分かる。これは MCMC と消滅テーブルによる時系列的な追跡を統合したことによる。EM アルゴリズムのみを用いて複数対象を追跡した場合 [20] と比べ、EM アルゴリズムの初期値依存性による追跡のロバスト性が改良されると考えられる。

7 おわりに

本研究では、床圧力センサから得られる時系列情報に対し、MCMC を用いて複数人物の追跡を行い、EM アルゴリズムと MDL 原理により追跡対象数を推定し、MCMC の推定結果と EM アルゴリズムの

推定結果を統合することで複数の人物位置を追跡対象数を認識しながら追跡する手法を提案した。本研究の応用分野としては、屋内の人物追跡の他に屋内ロボットの制御 [21] などあげられる。

謝辞

本研究の過程で、特に MDL 原理について有益な助言を頂いた和歌山大学の中村恭之 助教授に感謝する。本研究の一部は、独立行政法人情報通信研究機構受託研究「ユビキタスホームのための人物行動監視システムの実装」の補助を受けている。

参考文献

- [1] Orr, R. J. and Abowd, G. D.: The Smart Floor: A Mechanism for Natural User Identification and Tracking, *Extended Abstracts of Conference on Human Factors in Computing Systems (CHI00)*, pp. 275–276 (2000).
- [2] Headon, R. and Curwen, R.: Recognizing Movements from the Ground Reaction Force, *Proc. Workshop on Perceptive User Interfaces(PUI01)*, pp. 1–8 (2001).
- [3] Andrieu, C., de Freitas, N., Doucet, A. and Jordan, M. I.: An Introduction to MCMC for Ma-




図 6: 反応したセンサ数と推定人数




図 7: EM アルゴリズムの時系列 x 座標値

chine Learning, *Machine Learning*, No. 50, pp. 5–43 (2003).

- [4] Gordon, N. J., Salmond, D. J. and Smith, A. F. M.: Novel Approach to Nonlinear/Non-Gaussian Bayesian State Estimation, *IEE Proc. F Rader and Signal Processing*, Vol. 140, No. 2, pp. 107–113 (1993).
- [5] 北川源四朗: モンテカルロ・フィルタおよび平滑化について, *統計数理*, Vol. 44, No. 1, pp. 31–48 (1996).
- [6] Isard, M. and Blake, A.: CONDENSATION – Conditional Density Propagation for Visual Tracking, *Int. J. Computer Vision*, Vol. 29, No. 1, pp. 5–28 (28).
- [7] Bar-Shalom, Y.: Tracking Methods in a Multi-target Environment, *IEEE Trans. Automatic Control*, Vol. AC-23, No. 4, pp. 618–626 (1978).
- [8] Isard, M. and MacCormick, J.: BraMBLE: A Bayesian Multiple-Blob Tracker, *Proc. IEEE Int.*

Conf. Computer Vision (ICCV01), Vol. 2, pp. 34–41 (2001).

- [9] Tweed, D. and Calway, A.: Tracking Many Objects Using Subordinated CONDENSATION, *Proc. the British Machine Vision Conf. (BMVC02)*, pp. 283–292 (2002).
- [10] Hue, C. and Cadre, J.-P. L.: Sequential Monte Carlo Methods for Multiple Target Tracking and Data Fusion, *IEEE Trans. Signal Processing*, Vol. 50, No. 2, pp. 309–325 (2002).
- [11] Särkkä, S., Vehtari, A. and Lampinen, J.: Rao-Blackwellized Monte Carlo Data Association for Multiple Target Tracking, *Proc. Int. Conf. Information Fusion (FUSION04)*, pp. 583–590 (2004).
- [12] Khan, Z., Balch, T. and Dellaert, F.: Efficient Particle Filter-Based Tracking of Multiple Interacting Targets Using an MRF-based Motion Model, *Proc. IEEE/RSJ Int. Conf. Intelligent Robots and Systems (IROS03)*, Vol. 1, pp. 254–259 (2003).
- [13] Sidenbladh, H.: Multi-Target Particle Filtering for the Probability Hypothesis Density, *Proc. Int. Conf. Information Fusion (FUSION03)*, pp. 800–806 (2003).
- [14] Dempster, A. P., Laird, N. M. and Rubin, D. B.: Maximum-Likelihood from Incomplete Data via the EM Algorithm, *J. Royal Statistics Society*, Vol. B39, pp. 1–38 (1977).
- [15] Rissanen, J.: Universal Coding, Information, Prediction, and Estimation, *IEEE Trans. Information Theory*, Vol. 30, No. 4, pp. 629–636 (1984).
- [16] Murakita, T., Ikeda, T. and Ishiguro, H.: Human Tracking using Floor Sensors based on the Markov Chain Monte Carlo Method, *Proc. Int. Conf. Pattern Recognition (ICPR04)*, pp. 917–920 (2004).
- [17] Djouadi, A., Snorrason, Ö. and Garber, F. D.: The Quality of Training-Sample Estimates of the Bhattacharyya Coefficient, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 12, No. 1, pp. 92–97 (1990).
- [18] Vermaak, J., Godsill, S. J. and Pérez, P.: Monte Carlo Filtering for Multi-Target Tracking and Data Association, *IEEE Trans. Aerospace and Electronic Systems*, Vol. 41, No. 1, pp. 309–332 (2005).
- [19] Matsumoto, M. and Nishimura, T.: Mersenne Twister: A 623-dimensionally Equidistributed Uniform Pseudorandom Number Generator, *ACM Trans. Modeling and Computer Simulation*, Vol. 8, No. 1, pp. 3–30 (1998).
- [20] Gauvrit, H., Cadre, J.-P. L. and Jauffret, C.: A Formulation of Multitarget Tracking as an Incomplete Data Problem, *IEEE Trans. Aerospace and Electronic Systems*, Vol. 33, No. 4, pp. 1242–1257 (1997).
- [21] 山本 大介他: 床圧力センサによる位置追跡を利用したロボットの移動制御—人物追従による実用性と親和性—, *ロボティクス・メカトロニクス講演会 2005 講演論文集*, No. 2P1-N-050 (2005).